

PERBANDINGAN DETEKSI DIABETIC MACULAR EDEMA PADA CITRA OPTICAL COHERENCE TOMOGRAPHY MENGGUNAKAN METODE TRANSFER LEARNING

Sarwo Pranoto¹⁾, Musfirah Putri Lukman¹⁾, Amrullah Al Mubarokah²⁾, M. Zaki Permana S²⁾

¹⁾ Dosen Jurusan Teknik Elektro Politeknik Negeri Ujung Pandang, Makassar

²⁾ Mahasiswa Jurusan Teknik Elektro Politeknik Negeri Ujung Pandang, Makassar

ABSTRACT

Diabetic macular edema is well-known as one of the causes of vision loss in patients with diabetic retinopathy. DME could be cured if it is detected and treated in the early stage. The detection of DME could be conducted by ophthalmologists by using OCT images. However, because of the high similarity between DME image and healthy image, it is a tedious job and time-consuming for ophthalmologists to diagnose DME by using the OCT images. The purpose of this research is to detect DME on the OCT image automatically by implementing Transfer Learning techniques. The dataset of OCT images was collected from Kaggle website. Then two pre-trained models using Transfer Learning techniques are used and reimplemented in this research namely MobileNet and VGG-16. The results show that MobileNet could achieve an accuracy of 69% while VGG-16 could reach an accuracy of 93%.

Keywords: *Diabetic Macular Edema, Transfer Learning, MobileNet, VGG-16*

1. PENDAHULUAN

Vision 2020 The Right to Sight yang dicanangkan oleh *World Health Organization* (WHO) dan *International Agency for the Prevention of Blindness* (IAPB) merupakan inisiatif global bertujuan untuk menurunkan prevalensi gangguan penglihatan dan kebutaan di dunia. Indonesia bertekad untuk aktif mendukung dan memberantas kebutaan ini dengan ikut menandatangani inisiatif global tersebut pada tahun 2000. Salah satu upaya yang dilakukan pemerintah Indonesia adalah dengan melakukan survei kebutaan cepat berbasis populasi atau dikenal dengan sebutan *Rapid Assessment of Avoidable Blindness* (RAAB) yang dilakukan di 15 provinsi di Indonesia. Survei tersebut memberikan gambaran bahwa Indonesia memiliki masalah kebutaan yang cukup serius. Angka kebutaan Indonesia mencapai 30% dan merupakan negara dengan angka kebutaan yang tertinggi di Asia Tenggara [1]. Untuk menanggulangi masalah kebutaan tersebut diperlukan program pencegahan kebutaan yang baik.

Salah satu masalah penglihatan yang dapat menyebabkan kebutaan adalah Diabetic Macular Edema (DME) yang diakibatkan karena komplikasi penyakit diabetes [2]. Meskipun DME dapat disembuhkan jika dapat dideteksi pada fase awal, tetapi banyak pasien terutama di daerah pedesaan kurang peduli terhadap penyakit tersebut [3]. Oleh karena itu, deteksi dini dan perawatan pasien DME memegang peranan penting dalam mencegah penderita Diabetic Retinopathy kehilangan penglihatannya. Beberapa penelitian untuk mendeteksi dan mendiagnosa DME telah dilakukan sebelumnya. Deteksi DME dengan menggunakan citra fundus mata dilakukan untuk mengetahui tanda-tanda retinopathy berupa penebalan lapisan retina [4], [5]. Selain itu, beberapa dokter mata menggunakan citra OCT sebagai panduan dalam mendiagnosa dan melakukan perawatan terhadap pasien DME [6]. Citra OCT digunakan karena informasi tentang struktur internal retina dapat diketahui. Selain itu, citra OCT dapat digunakan untuk mengenali gejala awal DME [7]. Walaupun citra OCT digunakan oleh para dokter mata dalam mendiagnosa DME, tetapi penggunaannya masih secara manual. Hal ini menyebabkan proses diagnosa menjadi lama karena adanya kemiripan yang tinggi antara citra OCT untuk DME dan normal [8]. Untuk itulah, beberapa penelitian dilakukan untuk membantu dokter mata mendeteksi DME melalui citra OCT secara otomatis. Beberapa penelitian dilakukan dengan mengembangkan algoritma seperti segmentasi dan klasifikasi untuk menganalisa secara otomatis citra OCT [9]–[16]. Selain itu, penelitian untuk mengklasifikasikan DME dengan menggunakan *machine learning* juga dilakukan oleh beberapa peneliti. *Machine learning* digunakan untuk mendeteksi DME dengan cara menggabungkan ekstraksi histogram dari *oriented gradient* dengan pola biner [17]. Meskipun, penelitian menggunakan *machine learning* telah digunakan, tetapi algoritma yang dikembangkan masih pada tahap awal dan masih terbuka untuk peningkatan.

Pada penelitian ini, teknik *transfer learning* akan digunakan untuk mendeteksi DME dengan mengklasifikasikan citra OCT kedalam kategori mata normal dan mata yang terkena DME.

¹ Korespondensi penulis: Sarwo Pranoto, Telp 08124078122, sarwo.pranoto@poliupg.ac.id

2. METODE PENELITIAN

2.1 Dataset

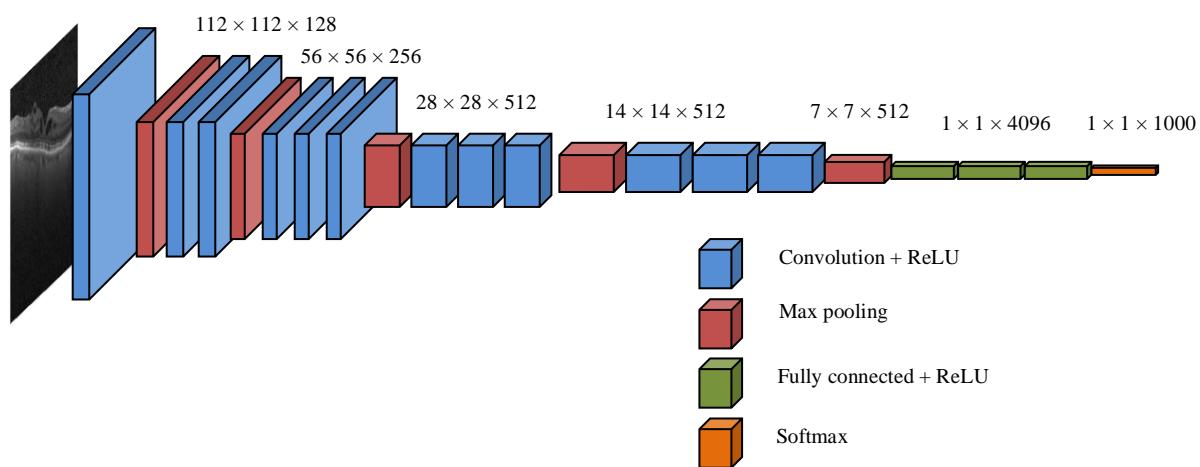
Pada penelitian ini dataset citra OCT diperoleh dari Kaggle [18] yang merupakan salah satu website penyedia dataset yang digunakan dalam bidang *machine learning*. Dataset terdiri dari 38163 citra OCT. Citra OCT tersebut terbagi menjadi dua kategori yaitu citra DME sebanyak 11598 dan citra normal sebanyak 26565. Masing masing kategori terdiri dari citra OCT dengan resolusi yang berbeda.

2.2 Klasifikasi Citra OCT

Penelitian ini fokus pada implementasi *pre-trained model* dengan teknik *transfer learning* untuk mendeteksi DME. *Pre-trained model* yang banyak digunakan dan diimplementasikan kembali dalam penelitian ini adalah MobileNet [19] dan VGG-16 [20]. Gambar 1 dan 2 menunjukkan arsitektur MobileNet dan VGG-16 yang digunakan dalam penelitian ini.

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5× Conv dw / s1	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
5× Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

Gambar 1. Arsitektur MobileNet



Gambar 2. Arsitektur VGG 16

2.3 Evaluasi Kinerja Model

Pada penelitian ini, untuk mengukur kinerja *pre-trained model* dalam deteksi DME pada citra OCT digunakan acuan *confusion matrix*. Berdasarkan confusion matrix, selanjutnya parameter *accuracy*, *recall*, *precision*, dan *F1-score* dihitung. Persamaan (1), (2), (3), dan (4) menunjukkan perhitungan *accuracy*, *recall*, *precision*, dan *F1-score*.

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (1)$$

$$\text{Recall} = \frac{TP}{(TP+FN)} \quad (2)$$

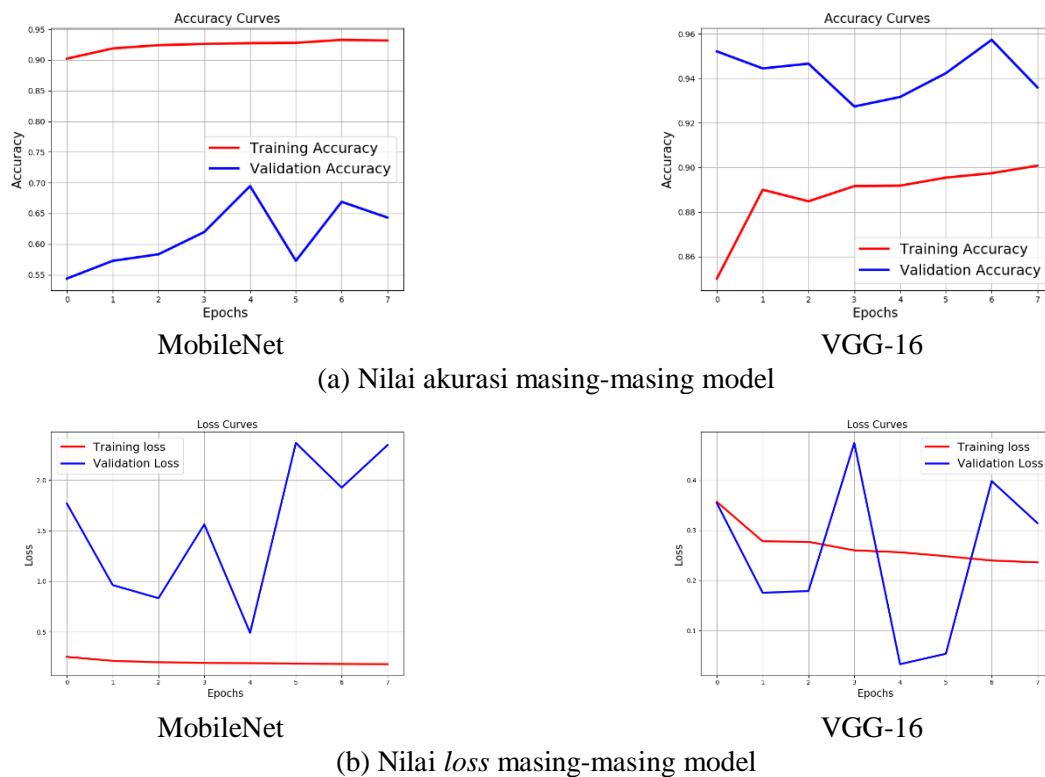
$$\text{Precision} = \frac{TP}{(TP+FP)} \quad (3)$$

$$F1 - Score = 2 \times \frac{(Recall \times Precision)}{(Recall+Precision)} \quad (4)$$

Dengan TP merupakan *True Positif* yang menunjukkan data positif yang diprediksi benar (positif). TN merupakan *True Negative* yang menunjukkan data negatif yang diprediksi benar (negatif). FP merupakan *False Positive* yang menunjukkan data negatif yang diprediksi sebagai data positif. Sedangkan FN merupakan *False Negative* merupakan data positif yang diprediksi sebagai data negatif.

3. HASIL DAN PEMBAHASAN

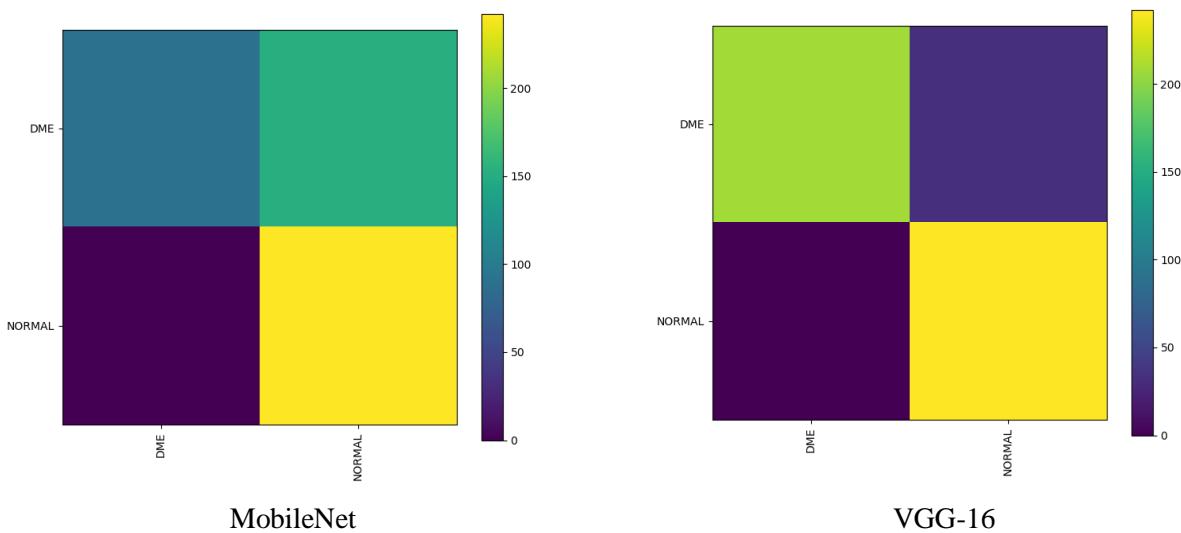
Gambar 3 menunjukkan performa pada *training dataset* dan *validation dataset*. Seperti yang terlihat pada Gambar 3a, akurasi pada saat *training* yang diperoleh oleh model MobileNet meningkat seiring dengan meningkatnya epoch. Akurasi *training* pada saat epoch terakhir diperoleh sebesar 93% sedangkan akurasi pada saat validasi diperoleh 64%. Dari grafik tersebut dapat diketahui terdapat perbedaan akurasi sebesar 29%. Akurasi *training* VGG-16 dicapai sebesar 90% sedangkan akurasi pada saat validasi sebesar 93%. Pada percobaan ini proses *training* akan berhenti jika nilai *minimum loss* tidak berubah selama tiga epoch berturut-turut seperti yang terlihat pada Gambar 3b.



Gambar 3. Performa masing-masing model pada *training dataset* dan *validation dataset*

Gambar 4 menunjukkan *confusion matrix* menggunakan *validation dataset*. Pada percobaan ini, menggunakan MobileNet, sebanyak 90 citra DME dari total 242 citra dapat dideteksi dengan benar. Semua citra normal dapat dideteksi dengan benar dengan menggunakan MobileNet. Sedangkan menggunakan VGG-16

sebanyak 202 citra DME dari total sebanyak 242 citra dapat dideteksi dengan benar. Sementara itu, menggunakan VGG-16 semua citra normal dapat dideteksi dengan benar.



Gambar 4 *Confusion matrix*

Tabel 1 menunjukkan parameter pengukuran hasil klasifikasi dari model MobileNet dan VGG-16. Seperti yang terlihat dalam Tabel 1, VGG-16 memiliki nilai akurasi yang lebih tinggi dibandingkan dengan MobileNet dalam mendeteksi DME pada citra OCT.

Tabel 1. Parameter pengukuran hasil klasifikasi

Model	Kelas	Precision	Recall	F1-Score
MobileNet	DME	1.00	0.37	0.54
	Normal	0.61	1.00	0.76
	<i>Accuracy</i>			0.69
	<i>Macro average</i>	0.81	0.69	0.65
	<i>Weighted Average</i>	0.81	0.69	0.65
VGG-16	DME	1.00	0.86	0.92
	Normal	0.88	1.00	0.93
	<i>Accuracy</i>			0.93
	<i>Macro average</i>	0.94	0.93	0.93
	<i>Weighted Average</i>	0.94	0.93	0.93

4. KESIMPULAN

Kesimpulan pada penelitian ini adalah:

- 1) Teknik *transfer learning* dengan model MobileNet dan VGG16 diimplementasikan dalam penelitian ini.
 - 2) Model MobileNet dan VGG 16 dapat mendeteksi DME pada citra OCT dengan akurasi yang berbeda.
 - 3) Model VGG 16 memiliki performa yang lebih baik dibandingkan dengan model MobileNet dalam mendeteksi DME pada citra OCT. Model VGG 16 memiliki akurasi sebesar 93% sedangkan MobileNet hanya memiliki akurasi sebesar 64%.

5. DAFTAR PUSTAKA

- [1] Dirjen P2PTM, *Peta Jalan Penanggulangan Gangguan Penglihatan di Indonesia Tahun 2017-2030*. 2018.

[2] S. Sharma, A. Oliver-Fernandez, W. Liu, P. Buchholz, and J. Walt, “The impact of diabetic retinopathy on health-related quality of life,” *Curr. Opin. Ophthalmol.*, vol. 16, no. 3, pp. 155–159, 2005.

[3] R. Gargeya and T. Leng, “Automated Identification of Diabetic Retinopathy Using Deep Learning,” *Ophthalmology*, vol. 124, no. 7, pp. 962–969, 2017.

- [4] L. Wu, "Classification of diabetic retinopathy and diabetic macular edema," *World J. Diabetes*, vol. 4, no. 6, p. 290, 2013.
- [5] J. Ding and T. Y. Wong, "Current epidemiology of diabetic retinopathy and diabetic macular edema," *Curr. Diab. Rep.*, vol. 12, no. 4, pp. 346–354, 2012.
- [6] M. E. J. van Velthoven, D. J. Faber, F. D. Verbraak, T. G. van Leeuwen, and M. D. de Smet, "Recent developments in optical coherence tomography for imaging the retina," *Prog. Retin. Eye Res.*, vol. 26, no. 1, pp. 57–77, 2007.
- [7] M. E. Brezinski *et al.*, "Optical coherence tomography for optical biopsy: Properties and demonstration of vascular pathology," *Circulation*, vol. 93, no. 6, pp. 1206–1213, 1996.
- [8] Y. Y. Liu *et al.*, "Computerized macular pathology diagnosis in spectral domain optical coherence tomography scans based on multiscale texture and shape features," *Investig. Ophthalmol. Vis. Sci.*, vol. 52, no. 11, pp. 8316–8322, 2011.
- [9] T. Hassan, M. U. Akram, M. F. Masood, and U. Yasin, "Deep structure tensor graph search framework for automated extraction and characterization of retinal layers and fluid pathology in retinal SD-OCT scans," *Comput. Biol. Med.*, vol. 105, no. July 2018, pp. 112–124, 2019.
- [10] R. Xu, S. Niu, Q. Chen, Z. Ji, D. Rubin, and Y. Chen, "Automated geographic atrophy segmentation for SD-OCT images based on two-stage learning model," *Comput. Biol. Med.*, vol. 105, no. September 2018, pp. 102–111, 2019.
- [11] T. Otani, S. Kishi, and Y. Maruyama, "T. Otani, S. Kishi, and Y. Maruyama, 'Patterns of diabetic macular edema with optical coherence tomography,' American Journal of Ophthalmology, vol. 127, no. 6, pp. 688–693, 1999," vol. 9394, no. 99, 2000.
- [12] S. Farsiu *et al.*, "Quantitative classification of eyes with and without intermediate age-related macular degeneration using optical coherence tomography," *Ophthalmology*, vol. 121, no. 1, pp. 162–172, 2014.
- [13] P. P. Srinivasan *et al.*, "Fully automated detection of diabetic macular edema and dry age-related macular degeneration from optical coherence tomography images," *Biomed. Opt. Express*, vol. 5, no. 10, p. 3568, 2014.
- [14] F. G. Venhuizen *et al.*, "Automated staging of age-related macular degeneration using optical coherence tomography," *Investig. Ophthalmol. Vis. Sci.*, vol. 58, no. 4, pp. 2318–2328, 2017.
- [15] K. Alsaih *et al.*, "Classification of SD-OCT volumes with multi pyramids, LBP and HOG descriptors: Application to DME detections," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2016-Octob, pp. 1344–1347, 2016.
- [16] A. Albarak, F. Coenen, Y. Zheng, and liverpoolacuk Frans Coenen, "Age-related Macular Degeneration Identification In Volumetric Optical Coherence Tomography Using Decomposition and Local Feature Extraction Spatial analysis of the optic disc in glaucoma View project Age-related Macular Degeneration Identification In Volu," no. January, 2014.
- [17] K. Alsaih, G. Lemaitre, M. Rastgoo, J. Massich, D. Sidibé, and F. Meriaudeau, "Machine learning techniques for diabetic macular edema (DME) classification on SD-OCT images," *Biomed. Eng. Online*, vol. 16, no. 1, 2017.
- [18] "Retinal OCT Images (optical coherence tomography) | Kaggle." [Online]. Available: <https://www.kaggle.com/paultimothymooney/kermany2018>. [Accessed: 15-Jun-2020].
- [19] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017.
- [20] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pimpinan institusi Politeknik Negeri Ujung Pandang, ketua dan staf UPPM Politeknik Negeri Ujung Pandang yang telah membantu terlaksananya penelitian ini.